下载APP

28 | 预测类产品（三）：从0打造一款“大白信用评分产品”

2021-03-01 刘海丰

成为AI产品经理 进入课程 >

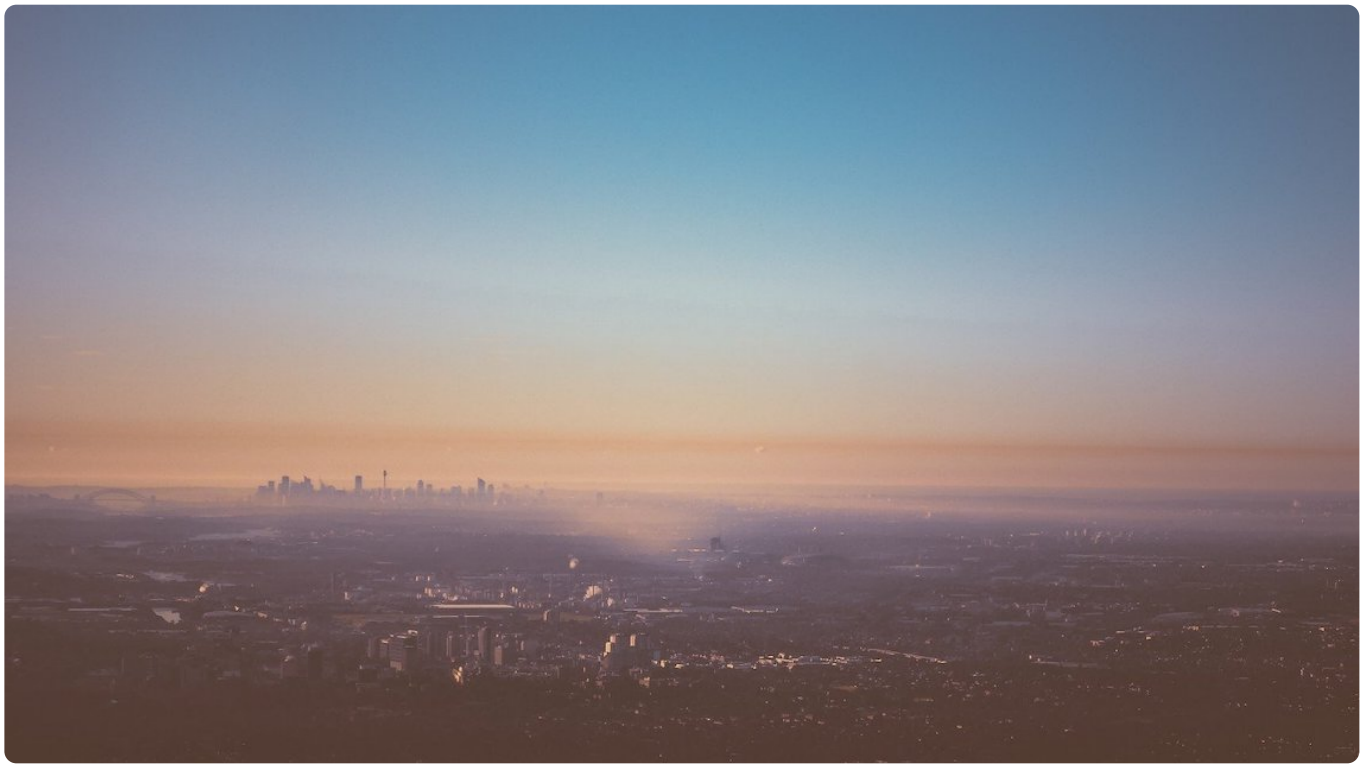

讲述：刘海丰
时长 10:35 大小 9.71M

你好，我是海丰。今天，我们接着来讲预测类产品的打造。我会以小白信用评分产品为例，来教你模拟构建一个大白信用评分产品，从而学习到机器学习在互联网金融行业的产品落地方法。

什么是小白信用评分产品呢？你可以看我下面给出的解释：

> 小白信用评分：指根据用户在京东的浏览、购物、投资理财、信用产品使用和履约情况、个人信息完整度等多个维度的数据，通过大数据算法，对用户的信用水平给出的综合评估的产品。评分越高表明用户的信用越好，受评用户就可以在京东及京东合作的享受优惠商业政策。

需要提前声明的是，构建“大白信用产品”的过程中，我们不会涉及任何与小白信用产品相关的内容，你只要学会构建的通用流程就可以了。整个构建流程可以分为四部分，分别是案例背景、特征构建、模型训练和模型评估。下面，我们就详细来说说。

案例背景

开头说了，我们要设计一个大白信用评分模型，那这个模型具体长什么样呢？一个标准的“大白信用模型”由五大维度构成，如下图所示。

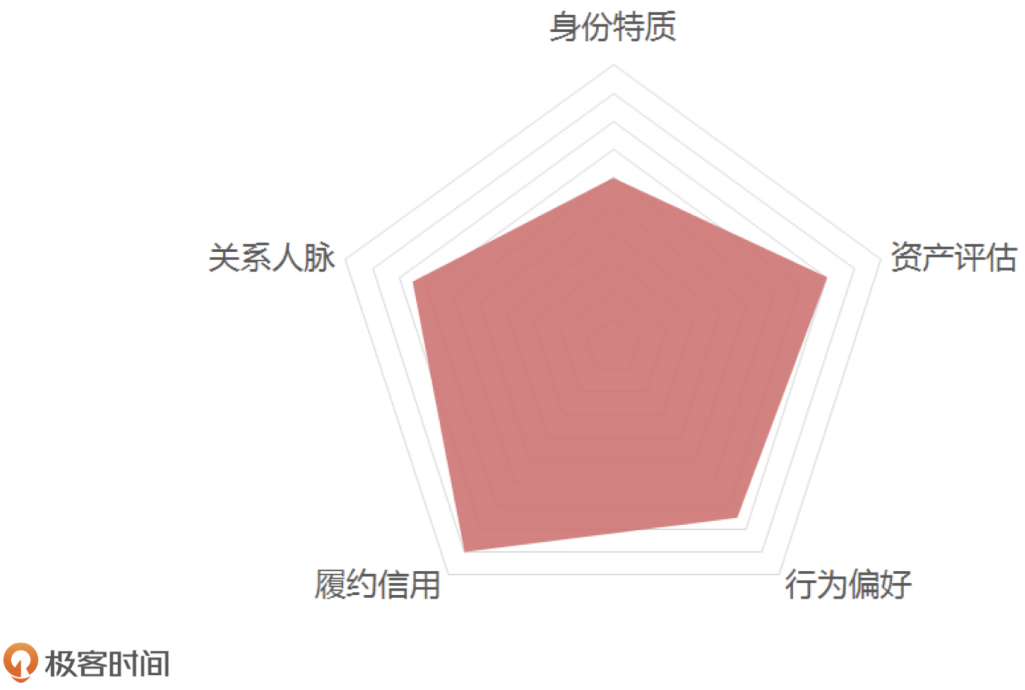

第一是身份特质，包括你的实名情况、社会属性、居住环境、教育情况，它们代表了你的出身、社会层次和稳定性，是一个人短时间内不会被改变的特质。

第二是资产评估：通过你提交的收入和资产信息来综合判断你的履约能力，包括社保、公积金、动产和不动产等。

第三是行为偏好：就是通过你的消费、缴费还款、公益活动等行为，判断你的行为特点，比如从消费偏好上看出你消费的高低。这部分数据对产品后续决策有很大的参考价值。

第四是履约信用：评估你在金融产品、电商平台和社会行为表现出来的履约和违约情况，比如看你历史的信用，来判断你的诚信度。

第五是人脉关系：这一步主要是对你的社交关系，人脉丰富程度进行评估。

通过这五个维度，我们除了能够判断一个人的信用到底好不好，还可以结合人的行为偏好来做更精准的个性化推荐。

在建模之前，我们先假设一个信用场景，比如通过“大白信用分”来决定用户是否可以免押金租相机。这个场景就是一个二分类问题。它的核心思路是，计算出用户在“大白信用”5 个维度上的违约概率，然后把它们综合起来计算出一个最终概率，再把它转化成一个实际的得分，也就是这个用户最终的“大白信用分”。

特征构建

接下来，我们就可以从刚才说的五大维度入手，来做“大白信用”评分模型的数据准备了。在做数据准备的时候，这 5 大维度还可以继续拆分成更多详细的分类和数据字段。比如“资产评估”就可以拆分成“固定资产”和“流动资产”等等，示例如下：

一级分类	二级分类	中文名
身份特质	实名信息	身份证已完善
身份特质	实名信息	护照已完善
身份特质	实名信息	学籍以完善
身份特质	实名信息	驾驶证已完善
...		
资产评估	固定资产	是否有车
资产评估	固定资产	是否有房
资产评估	流动资产	最近三个月流动资产日均
资产评估	流动资产	最近一个月理财产品总收益
资产评估	流动资产	最近三个月理财产品总收益
资产评估	流动资产	最近一年理财产品总收益
...		
行为偏好	消费行为	最近一年消费总金额
行为偏好	消费行为	最近一年数码品类消费总金额
行为偏好	消费行为	最近一年母婴品类消费总金额
行为偏好	消费行为	最近一年汽车品类消费总金额
...		
履约信用	逾期历史	最近一年 M1 次数
履约信用	逾期历史	最近一年 M3 次数
履约信用	守约历史	最近一年守约次数
...		
人脉关系	人脉指标	社交影响力指数
人脉关系	人脉指标	最近一年人脉圈稳定度
...		

极客时间

当然，在实际工作中，对于产品级数据模型构建来说，上面的数据信息还远远不够，我们还需要增加更多的**原始数据和扩展数据**。

原始数据就是存储在业务系统中的基础字段，比如日交易额、下单量、点击或搜索次数等原始字段信息。扩展数据是原始数据加工转化后的数据，一般有三种生成方式：按照时间维度衍生，如最近 1 个月或者 3 个月交易额；通过函数衍生，如最大或最小交易额，以及交易额方差；通过比率衍生，如“最近 1 个月交易额 / 最近 3 个月交易额”。

下一步就是对这些特征数据进行处理了。

在真实工作中，特征处理和选择是一个循环迭代、优化的过程，所以在业务前期，我们要尽可能多地抽取数据特征。特征处理的方法可以分为三种，分别是**特征的通用处理，数值型特征处理和字符串特征处理。**

特征的通用处理

特征的通用处理是我们在拿到特征数据之后都需要做的，包括**数据分布分析、缺失值处理与异常值校验。**

首先是特征数据的分布分析，我们要先通过数据可视化的方式查看数据的分布情况，然后对分布不均衡的数据采用“随机欠采样”、“随机过采样”或“SMOTE 算法”进行处理。这和我们上节课讲的一样，我就不再重复了。

其次，对“大白信用评分产品”中的数值型和字符串型字段进行缺失值和异常值检验，我们可以采用补充缺失值、或者直接剔除掉无效字段的方式进行处理。

数值型特征处理

对于数值型特征的处理，我们主要是看特征的 IV 值，因为 IV 值衡量了各特征对 y 值的预测能力。例如，下面是我们对员工工作信息模型的特征相关性排序。

feature	IV	comment
achievement_score	0.72808	业绩积分
end_score	0.66843	期末积分
end_level	0.65878	期末等级
job_level	0.57832	工作职级
entry_days	0.4432	在职时长
...	...	...

极客时间

需要注意的是，IV 值并不是越大越好。根据不同场景 IV 值的取值有所不同，实际的场景中，我们可以选择 IV 值大于 0.1 的指标。

除此之外，我们还要对特征进行归一化处理，来消除数据特征之间的量纲影响，让不同指标之间具有可比性。比如交易额和交易次数，这两个指标就没有可比性。我们通常使用的

归一化方法有线性函数归一化和零均值归一化。

线性函数归一化也称为最大值 - 最小值归一化，原理是将数据映射到 [0, 1] 的范围内，公式为：$x' = \frac{X - X_{min}}{X_{max} - X_{min}}$。

零均值归一化的原理是将数据映射到均值为 0，标准差为 1 的分布上，公式为：$x' = \frac{x - \bar{X}}{S}$。

字符串特征处理

对于字符串特征的处理主要就是对字符串做离散化，也就是将字符串映射到一个个离散的区间中。字符串离散化的目的是将变量数值化，因为数值化后的变量才能应用到数学模型中。

以“身份特质”为例，如果你的学历是硕士，那么我们该如何处理这个字段呢?

学历	分数
小学	[0, 20]
初中	[20, 40]
高中	[40, 60]
本科	[60, 80]
硕士	[80, 90]
博士	[90, 100]

极客时间

如表格所示，我们把 100 分分成 6 段，小学是 0～20，初中是 20～40，高中是 40~60，以此类推，我们直接把字符串映射到一个个的分段区间中就可以了。这里的具体取值按照业务常识设置的，我们只要做到逻辑上没有问题就行了。

模型训练

处理完数据，我们就要开始训练模型了。不过在那之前，我们要先选择算法。因为这是一个二分类问题，所以我们要选择二分类算法，又因为现在是项目前期，所以我们可以选择

相对简单的算法模型进行实验，比如逻辑回归模型。接下来，我们就可以按照如下步骤进行操作了 。

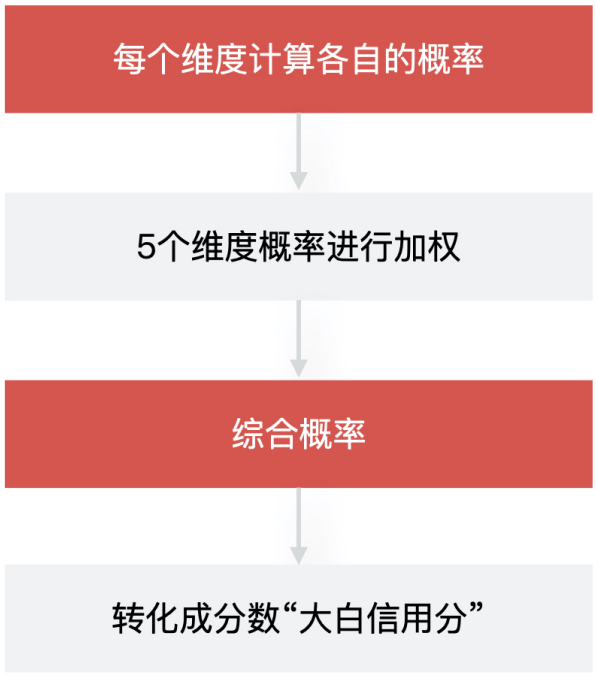

极客时间

我们以“履约信用”维度为例，假设“履约信用”包含的字段有最近一个月需还款金额 x_1，最近一个月逾期金额 x_2，最近一个月消费金额 x_3。根据 LR 公式，我们可以计算得到你违约的概率：$P = sigmod(y) = \frac{1}{1+e^{-y}} = \frac{1}{1+e^{-(ax_1+bx_2+cx_3))}}$。

其中，P 为用户违约的概率，a、b、c 为逻辑回归模型的拟合系数。

通过这个方法，我们依次计算出 5 个维度（身份特质、资产评估、行为偏好、履约信用、关系人脉）的概率，分别为 0.1、0.2、0.3、0.4、0.5。然后，我们再假设每个维度的权重都为 0.2，具体如下表所示：

	身份特质	资产评估	行为偏好	履约信用	关系人脉
维度权重	0.2	0.2	0.2	0.2	0.2
违约概率	0.1	0.2	0.3	0.4	0.5
综合违约概率	0.2 * 0.1 + 0.2 * 0.2 + 0.2 * 0.3+0.2 * 0.4 + 0.2 * 0.5 = 0.3				

极客时间

最后，我们还需要将综合概率 P 转化为实际的数值，转化公式为：$score = (1 - P) \times A + B$

其中，分数区间为 [200, 1000]，所以 A=800，B=200，然后我们再将上面的综合违约概率带入公式，就能得到你最后的大白信用分了，它等于 760。

当然，真实产品的模型构建过程肯定更为复杂，但它们的核心思想是一致的，**都是先划分维度，然后准备每一个维度的数据特征，对它们进行特征处理，构建好训练集和测试集，通过分类算法计算每一个维度的概率分，再通过加权的方式得出综合概率分，最终转化成具体的分数，这就是最终的信用得分了。**

模型评估

得到预测结果之后，我们要对模型进行抽样评估。**对于信用评分模型，我们只需关注两个重要的指标：混淆矩阵和 KS 值。**

比如说，在得到的预测结果中，60 分为切分点，60 以下我们认为会违约，60 分以上我们认为不会违约，我们预测可能会违约的是 180 人，不会违约的是 220。但在实际表现上，违约有 220 人，未违约有 280 人，相应的混淆矩阵如下：

混淆矩阵		预测值	
		违约	未违约
真实值	违约	TP=100	FN=20
	未违约	FP=80	TN=200

极客时间

这样我们就能计算出模型的准确率和召回率了：

模型的准确率的计算是：$\frac{TP+TN}{TP+TN+FP+FN} = \frac{100+200}{100+20+80+200} = 0.75$

模型的召回率的计算是：$\frac{TP}{TP+FN} = \frac{100}{100+20} = 0.83$

从结果上来看，模型的效果还是不错的。

相应的，我们还可以将 10 分、20 分、30 分这些分数分别作为切分点，得到一系列的混淆矩阵和对应的准确率和召回率，以及 TPR 和 FPR。我们把每一个切分点所对应的 TPR 和 FPR 相减，得到的最大值就是这个模型的 KS 值。

KS 的具体计算过程，你可以参考第 20 讲，这里我就不多说了。不过，最终 KS 值可以直接通过算法工程师的代码跑出来，不需要我们手工计算。

小结

这节课，我们一起打造了一个“大白信用评分产品”。还是和前几节课一样，想要成为金融风控方面的产品经理，你要从能力、技术和岗位这三方面进行准备。

在能力方面，金融行业的数据比较成熟，所以数据来源很多，这就要求产品经理对于数据源的成熟度和稳定性有**把控能力**。并且，如果我们想在项目前期尽快赢得客户认可，还要具备良好的**沟通能力和快速的反馈能力**。因此，相比于数据分析师这样的岗位，我们要注意锻炼自己能够站在产品、公司以及客户这三方角度来分析问题，提出自己的想法。

在技术方面，我们要理解机器学习算法模型。更具体点来说，你要理解逻辑回归、决策树、GBDT、随机森林、神经网络这些常用算法的原理、应用场景和优缺点，具体的内容你可以回顾算法技术能力篇。

在岗位方面，因为互联网金融的核心是风控，而风控领域的产品经理岗位，又可以细分为风控策略产品、系统产品，随着 AI 能力的普及，又有了风控 AI 产品经理等等岗位。如下是一张风控 AI 产品经理的 JD，你可以看一看。

职位诱惑：

金融科技

职位描述：

- 职位职责
1. 负责金融科技ToB能力的输出，联邦学习、决策引擎、特征平台等产品设计；
2. 负责与业务部门沟通，调动研发及相关资源，推动建设和优化风控管理机制；
3. 负责产品实施与推进，确保研发和测试完全理解需求，保证产品质量和进度；
4. 持续了解行业发展，将业内最新风控产品技术，应用于风控产品体系建设中；

- 职位要求
1. 大学及以上学历，数学、经济、统计学、计算机相关专业优先；
2. 五年以上互联网产品经验，至少二年以上消费金融风控业务经验；
3. 工作积极主动，逻辑性强，认真负责，良好的沟通和执行能力；
4. 能够输出优质的PRD、策略规则、界面原型、流程图等产品文档；
5. 技术转产品、懂机器学习、关系型数据库、决策引擎的优先考虑；

并且，我也把这节课和上节课产品经理岗位之间的区别总结在下表中，希望你能更直观地理解。

	预测类 AI 产品经理	风控类 AI 产品经理
应用行业	互联网	金融机构
算法选型	所有	侧重可解释性强的算法， 比如逻辑回归、决策树
行业经验	弱	强
客户分类	to C 居多	to B 居多

极客时间

课后讨论

在这里，我想请你谈一谈你对“芝麻信用分”和“小白信用分”的理解，他们的分数的取值范围分别是多少，为什么这样设定？

期待在留言区看到你的思考，我们下节课见！

提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 27 | 预测类产品（二）：从0打造一款预测用户复购意向的产品

下一篇 29 | 自然语言处理产品：从0打造一款智能客服产品

精选留言 (1)

写留言

Rosa rugosa
2021-03-16

芝麻信用与小白信用评分的取值范围是【200，1000】，这样取值是为了更具体的体现用户的信用状况，对用户信用进行更细致的划分。同时，在做模型验证的时候，更清楚的看到模型预测的能力（因为分数大，放大了模型的效果）

展开